



VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
INFORMATIKOS INSTITUTAS
KOMPIUTERINIO IR DUOMENŲ MODELIAVIMO KATEDRA

Magistro baigiamasis darbas

Išminavimo drono magnetometro įrašų analizė sprogmenims aptikti

Analysis of demining drone magnetometer recordings for explosives detection

Atliko:

Domantas Kuklys

Vadovas:

prof. dr. Aistis Raudys

Vilnius
2026

Turinys

Santrauka	4
Summary	5
Įvadas	6
1. Literatūros apžvalga	7
1.1. Geofizinių tyrimų būdai	7
1.1.1. Georadaras (GPR)	7
1.1.2. Elektromagnetinės indukcijos metodas	8
1.1.3. Elektrinės varžos tomografija	8
1.1.4. Magnetometras ir gradiometras	9
1.2. Anomalijų ieškojimo algoritmai	10
1.2.1. Vietinio nukrypimo faktoriaus algoritmas	10
1.2.2. Wavelet transformacijos algoritmas	11
1.2.3. Analitinio signalo amplitudės algoritmas (AAS)	12
2. Duomenų atranka	14
2.1. Sintetiniai duomenys	14
2.2. Realūs duomenys iš internetinių šaltinių	15
2.3. Realūs duomenys iš realių skenavimų Lietuvoje	17
3. Eksperimentai	20
3.1. Naudotos priemonės	20
3.2. Eksperimento eiga	20
3.2.1. Wavelet transformacijos algoritmas	20
3.2.2. Vietinio nukrypimo faktoriaus algoritmas	20
3.2.3. Analitinio signalo amplitudės algoritmas	21
4. Duomenų apdorojimas	22
5. Rezultatų aptarimas	25
5.1. Wavelet transformacijos algoritmas	25
5.1.1. Sintetinis signalas	25
5.1.2. Realaus skenavimo su MagNIMBUS magnetometru duomenys iš internetinio šaltinio	25
5.1.3. Realaus skenavimo su DRONEmag GSMP-35U magnetometru duomenys iš internetinio šaltinio	26
5.1.4. Realaus skenavimo duomenys iš realių skenavimų	27
5.2. Vietinio nukrypimo faktoriaus algoritmas	29
5.2.1. Sintetinis signalas	29
5.2.2. Realaus skenavimo su MagNIMBUS magnetometru duomenys iš internetinio šaltinio	30
5.2.3. Realaus skenavimo su DRONEmag GSMP-35U magnetometru duomenys iš internetinio šaltinio	31
5.2.4. Realaus skenavimo duomenys iš realių skenavimų	32

5.3. Analitinio signalo amplitudės algoritmas	34
5.3.1. Sintetinis signalas	34
5.3.2. Realus skenavimo su MagNIMBUS magnetometru duomenys iš internetinio šaltinio	35
5.3.3. Realus skenavimo su DRONEmag GSMP-35U magnetometru duomenys iš internetinio šaltinio	36
5.3.4. Realus skenavimo duomenys iš realių skenavimų	37
Išvados ir rekomendacijos	40
Ateities tyrimų planas	41
Literatūros šaltiniai	42

Santrauka

Šiame darbe analizuojami sprogmenų aptikimo automatizavimo algoritmai. Atlikta trijų metodų analizė: vietinio nukrypimo faktoriaus, wavelet transformacijos ir analitinio signalo amplitudės algoritmų. Šiame darbe aptariamos visų trijų metodų stipriosios ir silpnosios pusės, pritaikant šiuos metodus sukurtiems sintetiniams duomenims, realiems magnetometro duomenims iš skenavimų Lietuvoje bei magnetometrų duomenims iš internetinio šaltinio. Tyrimo rezultatai parodė, jog algoritmų efektyvumas priklauso nuo naudojamo magnetometro bei pasirinktų algoritmo parametrų. Realų skenavimų Lietuvoje atveju geriausius rezultatus parodė analitinio signalo amplitudės algoritmas, identifikavęs 71% sprogmenų lokacijų. Vis dėlto nė vienas iš nagrinėtų algoritmų nesugebėjo identifikuoti visų sprogmenų skenavimų Lietuvoje metu, todėl nagrinėtus algoritmus siūloma naudoti tik kaip pagalbines priemones sprogmenų paieškai.

Raktiniai žodžiai: magnetometras, anomalijų aptikimas, UXO, vietinio nukrypimo faktoriaus (LOF) algoritmas, wavelet transformacijos algoritmas, analitinio signalo amplitudės (AAS) algoritmas.

Summary

Analysis of demining drone magnetometer recordings for explosives detection

This research analyzes algorithms for automating the detection of explosives. Three methods were analyzed: local outlier factor (LOF), wavelet transformation, and amplitude of the analytic signal (AAS) algorithms. The study discusses the strengths and weaknesses of all three methods, applying these methods to synthetic data, real magnetometer data from scans in Lithuania, and magnetometer data from an online source. The results of the study showed that the effectiveness of the algorithms depends on the magnetometer used and the selected algorithm parameters. In the case of real scans in Lithuania, the best results were shown by the amplitude of the analytic signal algorithm, which identified 71% of the explosive locations. However, none of the algorithms were able to identify all neutralized explosives during scans in Lithuania, so it is recommended that the algorithms be used only as auxiliary tools for searching for explosive devices.

Key words: magnetometer, anomaly detection, UXO, Local Outlier Factor (LOF) algorithm, wavelet transformation algorithm, Amplitude of the analytic signal (AAS) algorithm.

Įvadas

Sprogmenų aptikimas yra vienas iš svarbiausių ir sudėtingiausių uždavinių karinėje bei humanitarinėje veikloje. Nesprogę sprogmenys palaidoti po žeme kelia didelį pavojų žmonių gyvybėms, ypač buvusiose karo zonose. Tradiciniai išminavimo būdai yra pavojingi ir reikalauja daug žmogiškųjų išteklių, todėl vis didesnis dėmesys yra skiriamas automatizuotoms technologijoms. Viena iš dažniausiai naudojamų pagalbinių technologijų sprogmenų aptikimui yra bepiločių orlaivių su įvairiais sensoriais technologijos.

Nors egzistuoja daug geofizinių tyrimų metodų, leidžiančių aptikti objektus po žeme, šiame darbe pagrindinis dėmesys skiriamas magnetometro sensoriaus technologijai. Magnetometrija fiksuoja Žemės magnetinio lauko pokyčius, kurie atsiranda dėl po žeme esančių feromagnetikų (sprogmenų). Šios technologijos pagalba galima aptikti įvairius artilerijos sviedinius, minas ir kitus metalinius sprogmenis paliktus buvusiose karo zonose. Gautus magnetometro duomenis analizuoja žmonės programinės įrangos pagalba. Šis procesas reikalauja daug laiko ir žmogiškųjų išteklių. Todėl šiame darbe nagrinėjami metodai, kurie gali padėti automatizuoti sprogmenų aptikimą iš magnetometro duomenų.

Šiame tyrime daugiausia dėmesio skiriama trims algoritmams, padedantiems automatizuoti sprogmenų aptikimą iš magnetometro duomenų: vietinio nukrypimo faktoriaus algoritmui, wavelet transformacijos algoritmui ir analitinio signalo amplitudės algoritmui. Vietinio nukrypimo faktoriaus algoritmas analizuoja pasirinkto taško kaimyninių taškų tankį ir nustato, ar pasirinktas taškas yra anomalija. Wavelet transformacijos algoritmas leidžia aptikti sprogmenis esant labai žemam signalo ir triukšmo santykiui. Analitinio signalo amplitudės algoritmas išryškina magnetinių anomalijų maksimumus, pasitelkdamas magnetinio lauko erdvinių išvestinių analizę. Visi šie metodai bus taikomi sukurtam sintetiniam duomenų rinkiniui ir iš realių skenavimų su magnetometrais gautiems duomenų rinkiniams. Taip bus siekiama įvertinti metodų efektyvumą bei tinkamumą praktiniam taikymui išminavimo kontekste.

Darbo tikslas - algoritmų, skirtų magnetometrų duomenų analizavimui ir sprogmenų aptikimui, efektyvumo įvertinimas ir palyginimas.

Darbo uždutys:

1. Atlikti literatūros analizę.
2. Atlikti eksperimentą pritaikant vietinio nukrypimo faktoriaus, wavelet transformacijos ir analitinio signalo amplitudės algoritmus.
3. Palyginti bei įvertinti gautus vietinio nukrypimo faktoriaus, wavelet transformacijos ir analitinio signalo amplitudės algoritmų rezultatus.
4. Parašyti išvadas.


1. Literatūros apžvalga

1.1. Geofizinių tyrimų būdai

Išminavimo darbams yra svarbus geofizinių metodų taikymas, kuris leidžia aptikti po žeme esančius objektus. Pasitelkiant įvairius žemės skenavimo būdus, galima efektyviai rasti po žeme esančius sprogmenis ir kitus objektus, nesukeliant pavojaus žmonių saugumui. Sprogmenų radimui dažniausiai yra naudojami keturi pagrindiniai geofizinių tyrimų būdai - georadaras (angl. *Ground Penetrating Radar*), elektromagnetinės indukcijos, elektrinės varžos tomografija, gradiometrai ir magnetometrai. Kiekvienas iš šių metodų turi savo privalumų ir trūkumų.

1.1.1. Georadaras (GPR)

Yra įvairių sensorių, kurių pagalba galima aptikti po žeme esančius objektus, tačiau georadaro technologija yra plačiausiai naudojama šiuolaikiniame pasaulyje. Didžiausias GPR privalumas, kuris pralenkia metalo detektorius ir magnetometrus, yra toks, jog šis gali aptikti ne metalinius objektus [15]. Pagrindinis georadaro veikimo principas yra skleisti didelio dažnio elektromagnetinius signalus į žemės paviršių ir analizuoti atspindžius nuo žemėje esančių objektų. Iš grįžusio signalo stiprumo ir laiko, kiek truko signalui pasiekti objektą ir grįžti į sensorių, yra apskaičiuojami tokie parametrai, kaip objekto gylis, dydis bei sudėtis [8].




1 pav. Georadaro atlikto skenavimo rezultatas.

Šis prietaisas labai tinka norint išsiaiškinti, kas slypi po žeme, neatliekant kasinėjimų, todėl yra naudojamas archeologijoje, sprogmenų ieškojime ar požeminių komunikacijų atradime. Vis dėlto, georadaro tikslumas priklauso nuo aplinkos veiksnių (dirvožemio sudėties ir reljefo) bei skenavimo metu naudojamos konfigūracijos ir parametrų. Esant sudėtingai dirvožemio struktūrai ar dideliai metalinių medžiagų koncentracijai po žeme, gali būti sunku aptikti požeminius objektus ar konstrukcijas [8]. Georadaro atlikto skenavimo rezultatą galima matyti 1 paveiksle.

1.1.2. Elektromagnetinės indukcijos metodas

Elektromagnetinės indukcijos (EMI) metodas yra pagrįstas Faradėjaus elektromagnetinės indukcijos dėsniu, kuris teigia, jog uždarame laidininke atsirandanti elektrovara yra tiesiogiai proporcinga magnetinio srauto kitimo greičiui [11], [26]. Norint aptikti po žeme esantį objektą, reikia išmatuoti sūkurinės srovės, kurią sukelia elektrovara, sukeltą magnetinį lauką. Šiuo principu yra paremtas metalo detektorius. EMI metodo veikimo procesas pavaizduotas 2 paveiksle. Šis metodas yra veiksmingas tik aptinkant metalinius objektus [26].




2 pav. Po žeme esančio metalinio objekto ieškojimo principas, pagal EMI metodą [26].

Šio metodo signalų analizė ir apdorojimas grindžiamas dviem kategorijomis: dažnių srities analize (FDEMI) ir laiko srities analize (TDEMI) [9].

1.1.3. Elektrinės varžos tomografija

Elektrinės varžos tomografijos (EVT) metodas, priklausantis geoelektrinių metodų šeimai, naudoja du elektrodus, kurie sukelia dirbtinę elektros srovę žemėje. Du elektrodai sukuria įtampą žemėje, kuri yra matuojama dar dviem kitais elektrodais [5]. Dažniausiai šis metodas taikomas aplinkos tyrimų, civilinės inžinerijos, hidrologinių tyrinėjimų, naudingųjų iškasenų paieškose bei archeologinio kartografavimo srityse [6].




3 pav. Elektrinės varžos tomografijos rezultatai skirtinguose gyliuose [6].

Šiuo metodu galima gauti dvimačio bei trimačio elektros varžos dirvožemyje pasiskirstymo vaizdus [19]. 3 paveiksle pavaizduoti elektrinės varžos tomografijos matavimo rezultatai skirtinguose gyliuose.


1.1.4. Magnetometras ir gradiometras

Geofiziniam aptikimui vienas pirmųjų ir plačiai naudojamų metodų yra magnetinis aptikimas [9]. Magnetometrija analizuoja nedidelius Žemės magnetinio lauko pakitimus, kitaip vadinamus "anomalijomis" [2]. Pats Žemės magnetinis laukas yra vienodas, tačiau šį iškreipia visokie geologiniai dariniai ar feromagnetinės medžiagos (sprogmenys, ginklai ir kt.), kurias magnetometras ir pažymi kaip anomalijas [2], [20]. Anomalijos pavyzdys pavaizduotas 4 pav.



4 pav. Anomalijos pavyzdys [9].

Žemės magnetinis laukas sukelia magnetinį momentą feromagnetinėse medžiagose, kurios vektoriškai sumuojasi su Žemės magnetiniu lauku. Būtent suminį magnetinį lauką ir fiksuoja magnetometras (5 pav.) [20].



5 pav. Feromagnetiko sukeltas magnetinis laukas, dėl kurio atsiranda anomalija [20].

Magnetiniai tyrimai yra patikimi ir greiti norint atrasti objektus esančius po žeme. Tačiau atliekant skenavimus su magnetometru šalia miesto, šio parodymai labai išsikraipo. Šiuos iškreipimus gali lemti tokie faktoriai kaip: elektros linijos, elektriniai bėgiai, pats dronas, prie kurio prikabinas magnetometras, ir t.t. Visi šie faktoriai kraipo magnetometro parodymus, kadangi skleidžia elektromagnetinę spinduliuotę [1], [4]. Triukšmo sumažinimui duomenyse naudojami tokie būdai kaip [1]:

- pritaikyti žemus dažnius praleidžiantį filtrą;
- magnetometrą pakabinti porą metrų žemiau negu dronas;
- ir kt.

Gradiometro privalumas, jog jis gali slopinti trikdžius iš aplinkos. Ši savybė ateina iš jo veikimo principo. Gradiometras matuoja magnetinio lauko gradientą (magnetinio lauko pokyčius tarp dviejų magnetinio lauko matavimo sensorių skirtingose erdvinėse vietose) [18].

1.2. Anomalijų ieškojimo algoritmai

Naudojant magnetometrą nesprogusių sprogmenų paieškai, galima pastebėti įvairias magnetinio lauko anomalijas. Norint tiksliai ir efektyviai atrasti sprogmenų vietas, reikia taikyti įvairius algoritmus, kurie šias anomalijas atpažintų. Šiame skyriuje bus aptarti trys algoritmai: vietinio nukrypimo faktoriaus algoritmas, kuris orientuojasi į anomalijų atradimą, Wavelet transformacijos algoritmas, leidžiantis aptikti sprogmenis net esant labai žemam signalo ir triukšmo santykiui, ir analitinio signalo amplitudės algoritmas, kuris išryškina magnetinių anomalijų maksimumus. Visi šie algoritmai leis lengviau atpažinti anomalijas iš magnetometro duomenų.

1.2.1. Vietinio nukrypimo faktoriaus algoritmas

Vienas žymiausių ir plačiai naudojamų anomalijų radimo algoritmų yra vietinio nukrypimo faktoriaus algoritmas, kurį 2000 metais sukūrė Markus M. Breuning. Nors tai, palyginus, yra nesudėtingas algoritmas, tačiau jis vis dar naudojamas net ir šiais laikais. Šis algoritmas yra ne tik itin greitas ar lengvai paralelizuojamas, bet ir lengvai pritaikomas tiesioginiams testavimo duomenims [3].

Vietinio nukrypimo faktoriaus algoritmas yra pagrįstas anomalijos radimu iš duomenų taško tankio su artimų kaimynų tam taškui tankiu. Pagrindinis šio algoritmo principas yra k artimiausių kaimynų radimas, kurie bus naudojami skaičiuojant vietinį nukrypimo faktorių bei duomenų tankį aplink pasirinktą tašką. Taškai, kurie yra neįprastai mažesnio tankio nei aplinkiniai taškai, gali būti laikomi anomalijomis [3].

Pagrindiniai algoritmo žingsniai gali būti apibūdinti taip [3]:

1. Apskaičiuojamas pasiekiamumo atstumas (angl. *Reachability distance*) tarp vieno duomenų taško ir jo aplinkinių taškų;
2. Turint pasiekiamumo atstumus, apskaičiuojama taško vietinė pasiekiamumo tankio reikšmė (angl. *Local Reachability Density*);
3. Taško vietinis pasiekiamumo tankis yra lyginamas su aplinkinių taškų tankiais, kuris leidžia gauti vietinį nukrypimo faktorių (angl. *Local Outlier Factor (LOF)*).

Vietinio nukrypimo faktoriaus algoritmas reikalauja nustatyti tik vieną artimiausių kaimynų skaičių, kuris yra žymimas k . Turint šį parametą, galima apibrėžti $kDistance(x)$ funkciją, kuri yra atstumas tarp duoto duomenų taško x ir jo k -ojo artimiausio kaimyno. Pasiekiamumo atstumas tarp taško x ir kito taško y apibrėžiamas taip [3]:

$$RD_k(x, y) = \max\{kDistance(y), dist(x, y)\}, \quad (1.1)$$

kur $dist(x, y)$ yra atstumas tarp x ir y .

Visi taškai, kurie nėra toliau už $kDistance(x)$ nuo x yra laikomi priklausantys kaimynams ir žymimi K . Taip pat kaimynystėje gali būti daugiau taškų, negu k . Vietinė pasiekiamumo tankio reikšmė duotam duomenų taškui x apskaičiuojama taip [3]:

$$LRD_k(x, y) = \frac{|K|}{\sum_{y \in K} RD_k(x, y)}, \quad (1.2)$$

kuris yra vidutinio pasiekiamumo atstumo tarp x ir jo kaimynų inversija. Reikšmė gauta iš 1.2 formulės yra lyginama su x kaimynų vietiniais pasiekiamumo tankiais, kad būtų apskaičiuotas vietinis nukrypimo faktorius [3]:

$$LOF_k(x) = \frac{1}{|K|} \sum_{y \in K} \frac{LRD_k(y)}{LRD_k(x)} = \frac{\sum_{y \in K} LRD_k(y)}{|K| LRD_k(x)}, \quad (1.3)$$

kuris parodo tankį, palyginant su jo kaimynais. 1.3 formulėje pateikta vertė gali būti vertinama taip [3]:

- Vertė artima 1 parodo, jog taško tankio vertė yra panaši jo kaimynų vertėms;
- Vertė didesnė už 1 parodo, jog taško tankio vertė yra mažesnė už jo kaimynų, todėl tai galima laikyti anomalija;
- Vertė mažesnė už 1 parodo, jog taško tankio vertė yra didesnė už jo kaimynų, todėl tai galima laikyti ne anomalija, o tipiniu duomenų tašku.

Apibendrinant, vietinio nukrypimo faktoriaus algoritmas leidžia greitai bei efektyviai atrasti anomalijas duomenų rinkinyje, lyginant duomenų taškų tankį su jų kaimynais.

1.2.2. Wavelet transformacijos algoritmas

Wavelet analizė yra tam tikra laiko arba erdvės mastelio signalo reprezentacija, kuri plačiai taikoma fizikoje, taikomojoje matematikoje bei signalų ir vaizdų apdorojime [21].

Wavelet transformacija gali būti išreikšta kaip koreliacijos operacija tarp įvesties signalo ir mastelio bazinės funkcijos, kuri dar vadinama motinine wavelet. Matematiškai koreliacija tarp įvesties signalo $f(x)$ ir motininės wavelet $h(x)$ yra išreiškiama taip [27]:

$$W(a, b) = C \int f(x) \frac{h\left(\frac{x-b}{a}\right)}{\sqrt{|a|}} dx, \quad (1.4)$$

kur a yra mastelio koeficientas, b - koordinačių perstūmimo reikšmė, C - konstanta, kuri privalo tenkinti priimtimumo sąlygą [27]:

$$C = \int \frac{H(v)}{|v|} dv < \infty, \quad (1.5)$$

kur H yra h Furjė transformacija. Priimtimumo sąlyga patvirtina, jog egzistuoja atvirkštinė wavelet transformacija, kurią apibrėžti galime taip [27]:

$$f(x) = C^{-1} \iint \frac{1}{a^2} W(a, b) \frac{h\left(\frac{x-b}{a}\right)}{\sqrt{|a|}} da db, \quad (1.6)$$

Daugelyje praktinių panaudojimų yra labai sunku gauti tęstinį (angl. *continuous*) mastelio koeficientą, tuo tarpu tęstinumą gauti su b yra daug lengviau. Norint išspręsti šią problemą, buvo apibrėžta nauja hibridinė wavelet transformacija. Šioje naujoje transformacijoje kintamasis b yra tęstinis, o mastelio koeficientas a - diskretus. Norint greitai įgyvendinti šią transformaciją, mastelio koeficientas a pasirenkamas kaip 2 laipsniai. Matematiškai tai atrodo taip [27]:

$$W(2^n, b) = C \int f(x) \frac{h\left(\frac{x-b}{2^n}\right)}{\sqrt{2^n}} dx, \quad (1.7)$$

ir taip pat atvirkštinė hibridinė wavelet transformacija atrodo taip [27]:

$$f(x) = C^{-1} \sum_n \int \frac{1}{2^{2^n}} W(2^n, b) \frac{h\left(\frac{x-b}{2^n}\right)}{\sqrt{2^n}} db, \quad (1.8)$$

1.2.3. Analitinio signalo amplitudės algoritmas (AAS)


Analitinio signalo amplitudės (angl. *Amplitude of the analytic signal (AAS)*) algoritmas yra gradientinis metodas, naudojamas magnetinio lauko anomalijų analizei, dažniausiai ieškant feromagnetinių objektų aplinkos tyrimuose. Šis metodas sukurtas kompleksinių funkcijų pagrindu ir remiasi Hilberto transformacijos savybėmis. AAS algoritmas naudingas norint nustatyti feromagnetinių objektų vietą bei gylį [22].

Dvimačiuose duomenyse AAS algoritmas apibrėžiamas kaip magnetinio lauko dviejų vertikaliųjų ir horizontaliųjų išvestinių kvadratų sumos kvadratinė šaknis, kur magnetinio lauko horizontaliosios ir vertikaliosios išvestinės sudaro Hilberto transformacijos porą. Trimačiuose duomenyse šis metodas gali būti aprašomas taip [22]:

$$|AAS(x, y)| = \sqrt{\left(\frac{\partial T}{\partial x}\right)^2 + \left(\frac{\partial T}{\partial y}\right)^2 + \left(\frac{\partial T}{\partial z}\right)^2}, \quad (1.9)$$

kur T - yra dipolio šaltinio sukurta magnetinio lauko anomalija. Analitinis signalas gali būti apskaičiuotas erdvinėje srityje (angl. *spatial domain*), naudojant skaitmeninį diferencijavimą, ir dažninėje srityje, pasitelkiant greitąją Furjė transformaciją [22].

Idealiuose dvimačiuose magnetiniuose šaltiniuose analitinio signalo amplitudės metodas grąžina simetrišką, varpo formos funkciją, kurios maksimumas yra tiesiai virš feromagnetinio šaltinio. Trimačių magnetinių šaltinių atveju grąžinta funkcija gali būti asimetriška, o jos maksimumo padėtis gali būti pasislinkusi nuo tikrosios magnetinio šaltinio vietos (6 pav.) [22].



6 pav. Normalizuotos analitinio signalo amplitudės funkcijos esant skirtingoms magnetizacijos inklinacijoms: a) orientuota magnetine šiaurės-pietų kryptimi; b) orientuota rytų-vakarų kryptimi [22].

Taigi, iš 6 pav. matome, jog analizuojant magnetinių objektų padėtį erdvėje, reikėtų būti atsargiems, kadangi analitinio signalo amplitudės maksimumas ne visada gali tiksliai nustatyti magnetinio šaltinio padėtį [22].

2. Duomenų atranka

2.1. Sintetiniai duomenys

Norint patikrinti anksčiau minėtus anomalijų atradimo algoritmus, buvo sukurti sintetiniai duomenys, imituojantys skenavimus su magnetometru. Tam buvo sukurtas 2D 100×100 taškų tinklėlis. Sukurtas signalas, sudarytas iš trijų komponentų:

1. Geologinio fono. Tai lėtai besikeičiantis gradientas (2.1), atitinkantis natūralius žemės magnetinio lauko pokyčius.

$$f_{fonas}(x, y) = 0,01x + 0,01y \quad (2.1)$$

2. Atsitiktinio triukšmo. Norint imituoti realaus skenavimo rezultatus, buvo pridėtas atsitiktinis triukšmas.
3. UXO anomalijų. Anomalijos buvo įterptos dviejose skirtingose vietose. Šios sprogmenų anomalijos buvo modeliuojamos kaip 2D Gauso funkcijos:

$$f(x, y) = A \exp \left(- \left(\frac{(x - x_0)^2}{2\sigma_X^2} + \frac{(y - y_0)^2}{2\sigma_Y^2} \right) \right), \quad (2.2)$$


kur

A - amplitudė,

x_0, y_0 - anomalijos centras X ir Y ašyse,

σ_X, σ_Y - anomalijos pasklidimas X ir Y ašyse.

Pirmos anomalijos Gauso funkcijos kintamųjų reikšmės: $A = 1, x_0 = 30, y_0 = 30, \sigma_X = 2, \sigma_Y = 2$. Antros anomalijos Gauso funkcijos kintamųjų reikšmės: $A = 1, x_0 = 70, y_0 = 60, \sigma_X = 5, \sigma_Y = 5$.



7 pav. Sukurtas sintetinis signalas.

Sudėjus visas komponentes, gautas signalas pavaizduotas 7 paveiksle.

2.2. Realūs duomenys iš internetinių šaltinių

Dalis realių duomenų naudotų šiam darbui buvo paimta iš "SPH Engineering SIA" paskelbto tyrimo apie skirtingų magnetometrų rezultatus ieškant sprogmenų. Šiame šaltinyje pateikiami duomenys yra surinkti realių bandymų metu. Visi bandymai aprašyti šiame šaltinyje buvo atlikti "SPH Engineering SIA" bepiločių orlaivių bandymų aikštelėje Baluožėje, Latvijoje. Keturi hektarai bandymų aikštelės yra apsupti miškų, kas reiškia, jog aikštelėje vyrauja mažas magnetinis fonas. Bandymo aikštelė gali būti laikoma nemagnetine, kadangi jos dirvožemį sudaro perdirbtos durpės. Dirvožemyje buvo užkastos 3 artilerijos sviedinių kopijos, kurių kalibrai yra 20 mm, 60 mm ir 105 mm. Šių artilerijos sviedinių kopijų nuotraukos pavaizduotos 8 paveiksle [13].



8 pav. Artilerijos sviedinių kopijos naudotos bandymams. Kairėje - 60 mm artilerijos sviedinio kopija, centre - 20 mm artilerijos sviedinio kopija, dešinėje - 105 mm artilerijos sviedinio kopija [13].


Kiekvienas magnetometras buvo skraidintas virš pasirinktos teritorijos skirtinguose aukščiuose. Aukštis buvo didinamas po kiekvieno praskridimo nuo 0,5 m iki 2,5 m, kiekvieną kartą aukštį didinant kas 0,5 metro. Minėti skirtingi aukščiai, naudoti šiame tyrime, rodo atstumą tarp užkasto bandinio ir magnetometro [13].

"SPH Engineering SIA" tyrime buvo naudojami keturi skirtingi magnetometrai [13]:

1. MagNIMBUS magnetometras.
2. MagDrone R3 magnetometras.
3. MagArrow II magnetometras.
4. DRONEmag GSMP-35U magnetometras.


Šiam darbui buvo pasirinkti MagNIMBUS (9 pav. kairėje) bei DRONEmag GSMP-35U (9 pav. dešinėje) magnetometrai. Šių magnetometrų pasirinkimo priežastis tokia, jog šių magnetometrų duomenys tyrimo metu yra saugomi .csv failo formatu, kas leidžia lengvai ir be papildomos programinės įrangos analizuoti duomenis. Likusių dviejų magnetometrų duomenys saugomi specialiu formatu, kas reikalauja papildomos programinės įrangos. Dažniausia drono skrydžio altitudė tokio tipo skenavimuose būna 0,5 m nuo žemės, kadangi tokioje altitudėje geriausiai matosi po žeme

esantys sprogmenys. Todėl šiam tyrimui bus tiriami duomenys, surinkti iš magnetometro duomenų, kai šio skrydžio altitudė nuo užkasto sprogmens buvo 0,5 metro.




9 pav. (a) MagNIMBUS magnetometras, (b) DRONEmag GSMP-35U magnetometras [13].

MagNIMBUS magnetometro duomenys susideda iš datos ir laiko, jutiklio ID, geografinių koordinatų (platumos ir ilgumos), bepiločio orientacijos, aukščio virš žemės paviršiaus, aukščio virš jūros lygio, bendro magnetinio lauko vertės (TMI) ir t.t. DRONEmag GSMP-35U magnetometro duomenis sudaro laikas, skenavimų data, magnetinio lauko stipris, geografinės koordinatės (ilguma ir platumą arba UTM rytinė koordinatė ir UTM šiaurinė koordinatė), aukštis virš jūros lygio ir t.t. Šiam darbui reikalinga platumą, ilgumą bei bendro magnetinio lauko vertė.



10 pav. MagNIMBUS (kairėje) ir DRONEmag GSMP-35U (dešinėje) magnetometrų vizualizuoti duomenys, kai aukštis nuo užkasto objekto yra 0,5 m.



11 pav. Artilerijos sviedinių kopijų užkasimo vietų vizualizacija pasitelkiant magnetometro duomenis, kai aukštis nuo užkasto objekto yra 0,5 m [13].

MagNIMBUS ir DRONEmag GSMP-35U magnetometrų duomenų vizualizacijos, kai drono skrydžio altitudė nuo užkasto objekto yra 0,5 m, pavaizduotos 10 paveiksle. Artilerijos sviedinių kopijų užkasimo vietos pateiktos 11 paveiksle.

2.3. Realūs duomenys iš realių skenavimų Lietuvoje

Dar vieni duomenys paimti iš realių skenavimų Lietuvoje, Kaišiadorių raj. (bandymų aikštelėje). Šių skenavimų tikslas buvo patikrinti MagNIMBUS magnetometro veikimą. Skenavimų zoną sudarė dvi aikštelės, kuriose buvo užkasti įvairių formų bei svorių nesprogę sprogmenys (12 pav.).



12 pav. Skenavimų zona sudaryta iš dviejų aikštelių, kuriose užkasti įvairių svorių bei formų nesprogę sprogmenys. Sprogmenų vietos pavaizduotos oranžinės spalvos apskritimais.

Dviejose aikštelėse iš viso buvo užkastas 21 sprogmuo. Kai kurių sprogmenų nuotraukos pavaizduotos 13 paveiksle. Užkastų sprogmenų parametrus, tokius kaip sprogmens pavadinimas, gylis, kuriame užkastas sprogmuo, ir sprogmens medžiaga, galima matyti 1 lentelėje.



13 pav. Kai kurių sprogmenų pavyzdžiai iš testavimo aikštelių.

1 lentelė. Užkastų sprogmenų parametrai.

Nr.	Objekto pavadinimas	Gylis (cm)	Objekto medžiaga
1	Granata F1	15	Plienas
2	Raketa PG7	30	Plienas-aliuminis
3	Prieštankinė mina TM62	5	Geležis-skarda
4	Minosvaidžio mina 82 mm (pusė)	50	Plienas
5	Minosvaidžio mina 120 mm	100-50	Plienas
6	Artillerijos sviedinys 76 mm šarvamušis	50	Plienas
7	Artillerijos sviedinys 122 mm (2/3 sviedinio)	80-40	Plienas
8	Artillerijos sviedinys 100 mm (skeveldra)	30	Plienas
9	Aviacinės bombos dalis (priekio dalis)	15	Plienas
10	60 mm apšviečiamosios minos galinė dalis (2 vnt.)	20	Aliuminis
11	Priešpėstinė mina POMZ-2M	15	Plienas
12	Artillerijos sviedinys 105 mm (I PK)	50	Plienas
13	Artillerijos sviedinys 76 mm (I PK) tusčias	40	Plienas
14	Artillerijos sviedinys 45 mm (šarvamušis)	40	Plienas
15	Minosvaidžio mina 120 mm (uodega)	30	Plienas
16	Minosvaidžio mina 60 mm	60-30	Aliuminis
17	Minosvaidžio mina 82 mm	70-30	Plienas
18	Artillerijos sviedinys 100 mm (pusė)	30	Plienas
19	Minosvaidžio mina 120 mm (pusė)	60	Plienas
20	Artillerijos sviedinys 122 mm (tūta)	40	Plienas
21	81-82 mm minų uodegos (2 vnt.)	30	Plienas

Kaip galima matyti iš 1 lentelės, sprogmenų pakasimo gylis svyruoja nuo 5 cm iki 1 m po žeme. Daugumą sprogmenų sudaro plienas, tačiau buvo užkastas ir aliuminis sprogmuo - siekiant įvertinti, ar magnetometro duomenyse iš tiesų nėra matomas aliuminis. Be pakasimo gylio ir sprogmens medžiagos reikšminga yra ir pačio sprogmens orientacija po žeme. Dalis sprogmenų buvo pakasta

horizontaliai, dalis vertikaliai arba pasvirę 45° kampu. Tokios pakastų objektų pozicijos leis pastebėti magnetinio lauko tendencijas, esant skirtingoms sprogmenų orientacijoms. Buvo norima ištirti ir magnetometro sprogmenų aptikimo priklausomybę nuo sprogmenų masės bei dydžio. Todėl pasirinkti objektai varijuoja mase nuo 0,5 kg iki 16 kg bei dydžiu (ilgiu arba skersmeniu) nuo 8,5-70 cm. Visų tyrimų metu magnetometras buvo skraidinamas pusės metro aukštyje virš žemės, taip pat buvo pasirinktas 2 m/s magnetometro greitis. Aikštelių gruntą daugiausia sudarė priemolis ir natūralus gruntinis sluoksnis.

3. Eksperimentai

Šio tyrimo eksperimentinėje dalyje buvo siekiama įvertinti algoritmų efektyvumą bei palyginti vietinio nukrypimo faktoriaus, wavelet transformacijos bei analitinio signalo algoritmų veikimą aptinkant sprogmenis (anomalijas) iš magnetometro duomenų. Eksperimentai atlikti naudojant sukurtus sintetinius duomenis, duomenis iš realių skenavimų, gautų iš internetinių šaltinių ir skenavimų Lietuvoje, kuriuose algoritmų rezultatai buvo lyginami su jau žinomomis neutralizuotų sprogmenų vietomis (11 pav. ir 12 pav.).

3.1. Naudotos priemonės

Visi eksperimentai buvo atlikti naudojant **Python** programavimo kalbą (3.8.8 versija) [24]. Analizei ir duomenų apdorojimui buvo naudotos tokios bibliotekos kaip:

- **NumPy** - duomenų analizei ir manipuliacijoms [10];
- **Pandas** - duomenų importavimui [16];
- **SciPy** - anomalijų centrų paieškai bei duomenų interpoliacijai [25];
- **PyWavelets** - Wavelet transformacijos algoritmo realizavimui [14];
- **scikit-learn** - vietinio nukrypimo faktoriaus algoritmo realizavimui bei duomenų normalizavimui [17];
- **scikit-image** - lokalių maksimumų (anomalijų) paieškai duomenyse, gautuose po wavelet transformacijos [23];
- **Matplotlib** - duomenų bei rezultatų vizualizacijai [12].

3.2. Eksperimento eiga

3.2.1. Wavelet transformacijos algoritmas

Wavelet transformacijos algoritmas buvo pritaikytas pasitelkiant **PyWavelets** biblioteką [14]. Buvo pritaikytas "db4" (Daubechies) wavelet tipas. Sintetinis signalas buvo apdorotas naudojant 3 lygio dekompoziciją, o realaus skenavimo signalams buvo pasirinktas pirmasis dekompozicijos lygmuo. Po dekompozicijos pritaikymo, duomenų rinkinys buvo rekonstruotas.

Norint atrasti anomalijas, sintetiniam signalui buvo nustatytas slenkstis (angl. *threshold*), kuris buvo lygus vidurkio ir keturių standartinių nuokrypių sumai. Realijų skenavimų atveju slenkstinė vertė buvo parenkama taikant procentilius. Vertės, didesnės už slenkstinę, buvo laikomos anomalijomis bei pažymėtos raudonais taškais. Užkastų sprogmenų lokacijos realių tyrimų metu pažymėtos juodais apskritimais. Šio eksperimento tikslas - įvertinti, kaip wavelet transformacijos algoritmo rezultatai priklauso nuo pasirinktos slenkstinės vertės.

3.2.2. Vietinio nukrypimo faktoriaus algoritmas

Vietinio nukrypimo faktoriaus algoritmas buvo pritaikytas naudojant **scikit-learn** biblioteką [17]. Pirmiausia turimi duomenys buvo normalizuoti, o vėliau buvo tiriamas algoritmo veikimas su skirtingais kaimynų skaičiais. Sintetiniam signalui pasirinktos kaimynų vertės: 10, 25, 40, 50.

MagNIMBUS ir DRONEmag GSMP-35U magnetometrų signalų iš internetinio šaltinio atveju pasirinktos kaimynų vertės lygios: 200, 300, 400, 500. Realų skenavimų Lietuvoje atveju abiem nagrinėtoms teritorijoms buvo taikyti vienodi kaimynų skaičiai: 15, 50, 100, 200.

Algoritmo rastos anomalijos pažymėtos raudonais taškais rezultatų vizualizacijose. Realų tyrimų atveju, užkastų sprogmenų lokacijos papildomai pažymėtos juodais apskritimais. Šis eksperimentas parodys, kaip vietinio nukrypimo faktoriaus algoritmo rezultatai sprogmenų paieškai priklauso nuo pasirinktų kaimynų skaičiaus.


3.2.3. Analitinio signalo amplitudės algoritmas

Analitinio signalo amplitudės algoritmas buvo taikytas magnetinių anomalijų lokalizavimui, remiantis magnetinio lauko erdvinėmis išvestinėmis. Pirmiausia duomenys buvo interpoliuoti, o vėliau buvo apskaičiuota analitinio signalo amplitudė. Anomalijų atrankai buvo pasirenkami skirtingi amplitudės slenksčiai procentiliais. Sintetinio signalo atveju buvo nagrinėjami 96, 97, 98 ir 99 procentilių slenksčiai. MagNIMBUS ir DRONEmag GSMP-35U magnetometrų signalams iš internetinio šaltinio buvo taikyti 80, 85, 90, 95 procentilių slenksčiai. Realų skenavimų Lietuvoje atveju abiem nagrinėtoms teritorijoms buvo taikomi vienodi amplitudės slenksčiai: 90, 95, 98, 99 procentiliai.

Vertės, viršijančios slenkstinę ribą (anomalijos), rezultatų vizualizacijose buvo pažymėtos raudonai. Taip pat realiuose tyrimuose užkastų sprogmenų lokacijos pažymėtos juodu apskritimu. Šio eksperimento tikslas - įvertinti, kaip analitinio signalo amplitudės algoritmo rezultatai priklauso nuo pasirinkto amplitudės slenksčio.

4. Duomenų apdorojimas


Realiomis sąlygomis gauti duomenys gali būti netikslūs ir triukšmingi, kas gali lemti algoritmų tikslumo praradimą. Realų skenavimų metu magnetometro rodmenims įtakos gali turėti drono įranga, įvairios elektromagnetinės bangos iš skirtingų šaltinių (mobiliojo ryšio bokštų, elektros perdavimo laidų) bei pačių skenavimų metu drono esanti skridimo trajektorija. Duomenų apdorojimui buvo naudojama SPH Engineering sukurta "GeoHammer" programinė įranga [7]. Duomenys iš realių skenavimų "GeoHammer" programinėje įrangoje pavaizduoti 14 paveiksle.



14 pav. Duomenys gauti iš realių skenavimų "GeoHammer" programinėje įrangoje.


Kairėje 14 pav. pusėje galima matyti drono skrydžių žemėlapi, centrinėje dalyje matomas magnetinio lauko pokytis per laiką, o dešinysis langas skirtas duomenų filtravimui ir interpoliavimui.

Pilnam duomenų sutvarkymui pirmasis žingsnis yra drono skrydžio žemėlapio apdorojimas. Drono apsisukimo vietos yra iškerpamos, kadangi šiose vietose būna didžiausias triukšmas. Dėl šio žingsnio drono misijos planavime yra prailginamas misijos plotas tose vietose, kur dronas apsisuks. 15 paveiksle atvaizduotas drono misijos žemėlapis po šios korekcijos.




15 pav. Drono misijos žemėlapis po drono apsisukimo vietų nukirpimo.

Antrasis žingsnis duomenų apdorojime yra drono skrydžio linijų ištrinimas, kurios kertasi su kitomis skrydžio linijomis. Vietos, kuriose dronas praskrido antrą kartą, gali būti triukšmingos. Magnetometras yra jautrus elektromagnetiniam triukšmui (kuris yra neprognozuojamas), todėl toje pačioje vietoje galima gauti dvi skirtingas magnetinio lauko reikšmes. Drono misijos žemėlapis po šios modifikacijos pavaizduotas 16 pav.




16 pav. Rezultatas gautas ištrinus linijas, kurios kerta kitas linijas.

Paskutinis žingsnis realių duomenų apdorojime yra žemų dažnių filtro pritaikymas magnetinio lauko duomenims. Žemų dažnių filtras išfiltruoja drono įrangos sukeltą triukšmą. Duomenys filtruojami dešiniajame lange (14 pav.) paspaudus "Žemų dažnių filtras" (angl. *Low-pass filter*) mygtuką.



17 pav. Žemų dažnių filtro meniu.

17 paveikslėlyje pateiktas išsiskleidęs žemų dažnių filtro meniu, kuriame reikia įrašyti reikšmę, iki kurios bus praleidžiami dažniai. Šiame darbe naudojamas 50 Hz dažnis, kuris yra rekomenduojamas "GeoHammer" programinės įrangos kūrėjų.



18 pav. Magnetinio lauko priklausomybės nuo laiko grafikas pritaikius žemų dažnių filtrą.

Žemų dažnių filtro korekcijos rezultatas magnetinio lauko vertėms pavaizduotas 18 pav. Šiame paveiksle ryški vientisa linija vaizduoja naujas magnetinio lauko vertes, o punktyrinė linija – buvusias vertes.


Apibendrinant, šiame skyriuje buvo aprašyti pagrindiniai duomenų apdorojimo etapai magnetometro duomenims iš realių skenavimų. Buvo pašalintos drono apsisukimo bei besikertančių linijų sritys, taip pat buvo pritaikytas žemų dažnių filtras su 50 Hz riba, kuris išfiltravo drono įrangos generuojamą triukšmą magnetiniame lauke. Po visų šių korekcijų duomenys tapo tinkami algoritmų taikymui ir tolimesnei analizei. Duomenų apdorojimo etapas yra esminis, norint pasiekti geresnius rezultatus nesprogusių sprogmenų aptikime.

5. Rezultatų aptarimas

5.1. Wavelet transformacijos algoritmas

5.1.1. Sintetinis signalas

Pritaikius Daubechies wavelet transformacijos algoritmo trečio lygio dekompoziciją, rezultata galima matyti 19 paveiksle.



19 pav. Wavelet transformacijos algoritmo rezultatų vizualizacija sintetiniam signalui.

Iš 19 paveikslo galima matyti, jog algoritmas sėkmingai aptiko abi anomalijas. Tai patvirtina ant anomalijų centrų esantys raudoni taškai, kurie atitinka anomalijų centrus.

Šie rezultatai parodo, jog wavelet transformacijos algoritmas gali gerai identifikuoti mažas bei dideles anomalijas, nepaisant signale esančio triukšmo. Tai parodo, jog wavelet pagrindu veikiantis metodas yra tinkamas tokio tipo tyrimams.


5.1.2. Realus skenavimo su MagNIMBUS magnetometru duomenys iš internetinio šaltinio

Pritaikius Daubechies wavelet transformacijos algoritmą realaus skenavimo MagNIMBUS magnetometro duomenims iš internetinio šaltinio, buvo tiriama, kaip skirtingi slenksčiai veikia anomalijų išryškinimą. 20 paveiksle pateikti rezultatai gauti taikant skirtingus slenksčius procentiliais nuo 75 iki 90 procentų.

20 paveikslo (a) dalyje pavaizduotas rezultatas, kai procentilinis slenkstis yra 75%. Matoma, jog su šiuo slenksčiu algoritmo pažymėtos vietos sutampa su užkastų objektų lokacijomis. Taip pat matoma, kad didelė dalis pažymėtų anomalijų yra skenavimo zonos kraštuose kartu su pavienėmis pažymėtomis anomalijomis matavimo zonoje.

Padidinus slenkstį iki 80%, galima pastebėti, jog algoritmo pažymėtos vietos vis dar sutampa su užkastais objektais, sumažėjo klaidingai pažymėtų anomalijų skaičius, o žymos aplink zonos kraštus išliko. Slenkstį didinant iki 85% ir 90%, matoma, kad šie slenksčiai yra per dideli, kadangi algoritmo pažymėtos vietos atitinka tik vieno užkasto sprogmenų vietą. Visuose rezultatų vizualizacijose matomos žymos zonos kraštuose. Šį rezultatą galima paaiškinti tuo, jog šiose srityse signalas nutrūksta, o wavelet transformacijos algoritmas yra jautrus tokiems staigiems signalo pokyčiams.


Taigi, wavelet transformacijos algoritmas realaus skenavimo su MagNIMBUS magnetometru duomenims iš internetinio šaltinio pažymėjo visų trijų užkastų objektų vietas su 75% ir 80% slenkstiniais procentiliais. Didinant slenkstį, algoritmo pataikymas sumažėjo.



20 pav. Wavelet transformacijos algoritmo rezultatai MagNIMBUS magnetometro duomenims iš internetinio šaltinio, taikant skirtingus procentilinius slenksčius: a) 75%, b) 80%, c) 85%, d) 90%.

5.1.3. Realus skenavimo su DRONEmag GSMP-35U magnetometru duomenys iš internetinio šaltinio

Šiame poskyryje pateikti rezultatai gauti pritaikius Daubechies wavelet transformacijos metodą internetiniams duomenims, kurie buvo gauti matavimus atliekant su DRONEmag GSMP-35U magnetometru. Rezultatų vizualizacijas su įvairiais procentilniais slenksčiais galima matyti 21 paveiksle.



21 pav. Wavelet transformacijos algoritmo rezultatai DRONEmag GSMP-35U magnetometro duomenims iš internetinio šaltinio, taikant skirtingus procentilinius slenksčius: a) 60%, b) 65%, c) 70%, d) 75%.


Slenkstį parinkus kaip 60%, pastebima, jog algoritmo pažymėtos vietos išsidėsčiusios per visą skenavimo zoną. Kai kurios žymos atitinka užkastų objektų vietas, tačiau yra atrandami tik 2 iš 3 objektų. Didelis skaičius žymų yra klaidingai pažymėtos sprogmenų lokacijos.

Slenksčio ribą pasirenkant kaip 65%, matomas klaidingai pažymėtų sprogmenų žymų sumažėjimas. Algoritmo taiklumas išlieka panašus kaip su 60% slenksčiu. Ribą didinant iki 70% arba 75% pastebima panaši tendencija kaip ir 5.1.2 poskyryje. Algoritmo tikslumas mažėja, lieka aptiktas tik vienas sprogmuo. Kaip ir ankstesniame poskyryje, su visais slenksčiais yra matomi pažymėti taškai zonos kraštuose.

Palyginus šiuos rezultatus su 5.1.2 poskyryje gautais rezultatais, atliekant matavimus su MAGNIBUS magnetometru, matomi minimalūs skirtumai. Atitinkamai parinkus slenksčius, rezultatai abiejuose poskyriuose yra ganėtinai panašūs. Vienintelis skirtumas yra pataikymo procentas. 5.1.2 poskyryje algoritmas sugebėjo atrasti visas tris sprogmenų vietas, kai šiame poskyryje algoritmas atrado tik 2 lokacijas iš 3. Tačiau tiek šiame, tiek 5.1.2 poskyryje gauti rezultatai rodo, jog wavelet transformacijos algoritmas gebėjo atpažinti užkastus sprogmenis. Taip pat, palyginus abiejuose poskyriuose aprašytus rezultatus, galima daryti prielaidą, jog algoritmo rezultatams įtakos turi ir pats magnetometras, su kuriuo buvo atlikti matavimai.

5.1.4. Realus skenavimo duomenys iš realių skenavimų

Šis poskyris aprašo wavelet transformacijos algoritmą, pritaikytą realiems skenavimams su skirtingais procentilniais slenksčiais. Kaip jau buvo minėta 2.3 poskyryje, matavimai buvo atlikti dviejose aikštelėse. Gauti rezultatai pateikti 22 ir 23 paveiksluose.




22 pav. Wavelet transformacijos algoritmo rezultatai pirmojoje skenavimo zonoje, taikant skirtingus procentilinius slenksčius: a) 85%, b) 90%, c) 92%, d) 93%.

22 pav. (a) dalyje pavaizduota pirmoji skenavimo zona su wavelet transformacijos algoritmo rezultatais, kai procentilis slenksis lygus 85%. Gauti rezultatai rodo, kad esant tokiam slenksčiui algoritmo pažymėtos anomalijos išsidėsto per visą matavimo zoną. Nors dalis algoritmo pažymėtų taškų atitinka sprogmenų vietas, tačiau dėl didelio klaidingai pažymėtų anomalijų kiekio nėra įmanoma patikimai nustatyti tikslų sprogmenų lokacijų.

Slenkstį padidinus iki 90% (22 pav. (b) dalis), stebimas klaidingai pažymėtų anomalijų sumažėjimas. Nors tikrosios sprogmenų vietos pradeda ryškėti, klaidingai pažymėtų anomalijų triukšmas vis dar yra pakankamai didelis, kad būtų patikimai atpažintos visos sprogmenų lokacijos.

Geriausias rezultatas gautas su 92% procentiliniu slenksčiu (22 pav. (c) dalis). Esant šiai ribai, algoritmas identifikavo 7 iš 10 sprogmenų vietų. Klaidingų žymų skaičius minimalus ir išsidėstęs per visą skenavimo zoną.

Taikant 93% procentilinį slenkstį, gautas rezultatas rodo, jog ši slenkstinė riba yra per didelė, kadangi visos algoritmo pažymėtos vietos išsidėsčiusios skenuotos teritorijos kraštuose. Toks rezultatas siejamas su staigiai nutrūkusiu signalu, kuris paaiškintas 5.1.2 poskyryje.



23 pav. Wavelet transformacijos algoritmo rezultatai antrojoje skenavimo zonoje, taikant skirtingus procentilinius slenksčius: a) 90%, b) 91%, c) 92%, d) 93%.

Wavelet transformacijos algoritmo rezultatai antrajai zonai, taikant 90% procentilinį slenkstį, pavaizduoti 23 paveikslo (a) dalyje. Kaip matoma, algoritmo pažymėtų anomalijų skaičius yra didelis bei išsiskaidęs per visą matavimą zoną. Tokia slenkstinė riba yra per žema, norint patikimai identifikuoti visas užkastų sprogmenų vietas.

23 paveikslo (b) dalyje pateikti algoritmo rezultatai, kai slenkstinė riba yra 91%. Stebimas klaidingai pažymėtų anomalijų skaičiaus mažėjimas, tačiau likęs pažymėtų anomalijų triukšmas vis dar yra ganėtinai didelis, todėl nėra įmanoma tiksliai atpažinti visų sprogmenų buvimo vietų.

Didžiausias algoritmo efektyvumas šiai teritorijai pasiektas taikant 92% procentilinį slenkstį (23 pav. (c) dalis). Esant šiai slenkstinei ribai, algoritmas identifikavo 4 iš 11 užkastų sprogmenų

lokacijų. Nepaisant sumažėjusio klaidingai aptiktų anomalijų skaičiaus, jos vis dar sudaro didelę dalį visų žymų ir yra pasiskirsčiusios visoje skenavimo zonoje.


Taikant 93% procentilinį slenkstį, buvo aptiktas tik vienas iš vienuolikos sprogmenų. Tai rodo, kad ši slenkstinė riba yra per didelė, kadangi visos algoritmo pažymėtos vietos išsidėsčiusios skenuotos teritorijos kraštuose. Toks rezultatas siejamas su staigiai nutrūkusiu signalu, kuris paašškintas 5.1.2 poskyryje.

Lyginant abiejų teritorijų analizės rezultatus, gautus pritaikius wavelet transformacijos algoritmą, galima teigti, jog šis metodas geba atpažinti magnetines anomalijas ir gali būti naudojamas kaip pagalbinė priemonė sprogmenų ieškojime. Vis dėlto reikia atidžiai parinkti slenkstinę ribą, kadangi algoritmo rezultatai yra jautrūs jos pasirinkimui, ir nuo to tiesiogiai priklauso aptikimo patikimumas.

5.2. Vietinio nukrypimo faktoriaus algoritmas

5.2.1. Sintetinis signalas

Pritaikius vietinio nukrypimo faktoriaus algoritmą sintetiniams duomenims su įvairiomis kaimynų vertėmis, rezultatai pavaizduoti 24 pav.



24 pav. Vietinio nukrypimo faktoriaus algoritmo rezultatai, kai kaimynų skaičius yra: a) 10, b) 25, c) 40, d) 50.

Kaip galima matyti, mažesnės kaimynų reikšmės ($k = 10$) lemia didelį klaidingų pažymėtų anomalijų kiekį. Didinant kaimynų kiekį ($k = 25, k = 40, k = 50$), pastebima tendencija, jog


algoritmo rezultatai tampa tikslesni, tai yra, jog algoritmas sėkmingai geba atpažinti tikras anomalijas. Algoritmas sugebėjo atpažinti didesnę anomaliją, tačiau mažesnioji anomalija liko neidentifikuota. Taip pat su didesnėmis k reikšmėmis algoritmas klaidingai atpažįsta tam tikrus kraštinius taškus, ypač apatiniame kairiajame kampe. Gauti rezultatai rodo, jog LOF algoritmo rezultatai labai priklauso nuo parinktų kaimynų skaičiaus.

Rezultatus palyginus su wavelet transformacijos algoritmo rezultatais sintetiniam signalui, galima teigti, jog wavelet transformacijos algoritmas yra patikimesnis bei efektyvesnis sintetinio signalo atveju. Tiek mažesnė, tiek didesnė anomalija buvo išryškinta bei atpažinta pasitelkiant wavelet transformaciją, kas nebuvo pasiekta taikant vietinio nukrypimo faktoriaus algoritmą. LOF algoritmas nesugebėjo identifikuoti mažosios anomalijos ir klaidingai pažymėjo kraštuose esančius taškus kaip anomalijas.

5.2.2. Realus skenavimo su MagNIMBUS magnetometru duomenys iš internetinio šaltinio

Pritaikius vietinio nukrypimo faktoriaus algoritmą MagNIMBUS magnetometro duomenims iš internetinio šaltinio, buvo vertinama, kaip pasirinktų kaimynų skaičius k lemia tikrųjų anomalijų aptikimą. 25 pav. esantys rezultatai rodo, jog didinant kaimynų skaičių LOF algoritme, aptinkamų taškų skaičius didėja.

Su mažesnėmis k ($k \leq 200$) reikšmėmis vietinio nukrypimo faktoriaus algoritmas aptinka tik didžiąją anomaliją. Tačiau, didinant kaimynų skaičių, matome, jog algoritmas pradeda aptikti ir mažesnes anomalijas. Geriausi rezultatai šiame eksperimente pasiekti, kai kaimynų skaičius buvo $k = 300$ ir $k = 400$. Šiais atvejais matoma, jog algoritmas identifikavo visas tikrąsias anomalijas su mažu klaidingų detekcijų skaičiumi. Kaimynų skaičiui pasiekus $k = 500$ klaidingų detekcijų skaičius padidėjo, tačiau visos tikrosios anomalijos yra identifikuotos.



25 pav. Vietinio nukrypimo faktoriaus algoritmo rezultatai su MagNIMBUS magnetometro duomenimis iš internetinio šaltinio, kai kaimynų skaičius yra: a) 200, b) 300, c) 400, d) 500.


Šio eksperimento gauti rezultatai rodo, jog priešingai nei su sintetiniais duomenimis, realiuose magnetometro duomenyse vietinio nukrypimo faktoriaus algoritmas geba aptikti mažesnes anomalijas, net esant dideliam foniniam triukšmui. Palyginus su 5.1.2 poskyryje gautais rezultatais, LOF algoritmo gauti rezultatai yra vienodi wavelet transformacijos algoritmo rezultatams. Abu šie algoritmai sugebėjo atpažinti tikrąsias magnetines anomalijas.

5.2.3. Realus skenavimo su DRONEmag GSMP-35U magnetometru duomenys iš internetinio šaltinio

Pritaikius vietinio nukrypimo faktoriaus algoritmą realaus skenavimo su DRONEmag GSMP-35U magnetometru duomenims iš internetinio šaltinio, buvo siekiama patikrinti atrastų sprogmenų kiekio priklausomybę nuo pasirinkto kaimynų skaičiaus. Kaimynų skaičiai buvo pasirinkti atitinkamai: 200, 300, 400 ir 500. Šiu rezultatų vizualizacijos pateiktos 26 paveiksle.

Iš 26 paveikslo matoma, kad kaimynų skaičiui esant $k = 200$ algoritmo pažymėtos anomalijos koncentruojasi aplink didžiausią anomaliją. Tačiau mažesnės anomalijos (mažesni sprogmenys) nėra pastebimos. Dalis algoritmo pažymėtų anomalijų yra pažymėta skenavimo zonos kraštuose. Panašus rezultatas su vienodu kaimynų skaičiumi buvo gautas ir 5.2.2 poskyryje.

Kaimynų skaičių didinant iki $k = 300$ matoma didesnė koncentracija aplink didžiausią anomaliją. Taip pat yra aptinkamas dar vienas sprogmuo, kuris nebuvo aptinkamas kaimynų skaičiui esant $k = 200$. Pastebima, kad dalis algoritmo pažymėtų anomalijų atsirado pavienėse skenavimo zonos vietose, kurios nėra susijusios su užkastais objektais. Tokios anomalijos gali būti siejamos su klaidingai pažymėtomis anomalijomis arba vizualiai nematomais feromagnetiniais objektais po žeme.



26 pav. Vietinio nukrypimo faktoriaus algoritmo rezultatai su DRONEmag GSMP-35U magnetometro duomenimis iš internetinio šaltinio, kai kaimynų skaičius yra: a) 200, b) 300, c) 400, d) 500.

Kaimynų skaičių pasirinkus kaip $k = 400$, matomas didesnis pažymėtų anomalijų telkinys aplink didžiausią magnetinę anomaliją bei anksčiau atrastą antrąjį objektą. Taip pat atrandamas trečiasis


sprogmuo, kas leidžia suprasti, jog didinant kaimynų skaičių, algoritmas geba pastebėti mažesnes magnetines anomalijas. Pavienių pažymėtų anomalijų skaičius padidėjo, tačiau šie žymėjimai koncentruojasi aplink tam tikrus taškus.

Vietinio nukrypimo faktoriaus algoritmo kaimynų skaičių padidinus iki $k = 500$, matomas didesnis algoritmo pažymėtų anomalijų tankis aplink visus užkastus objektus. Taip pat matomas pažymėtų anomalijų koncentracijos padidėjimas aplink pavienius skenavimo zonos taškus, kas gali reikšti, jog šiose vietose po žeme gali būti neatrasti feromagnetiniai objektai.

Taigi, pritaikius LOF algoritmą DRONEmag GSMP-35U magnetometro duomenims, matoma aiški tendencija, jog didinant algoritmo kaimynų skaičių, algoritmas tampa jautresnis mažesnių magnetinių anomalijų sritims. Šiuo atveju LOF algoritmas atrado visus užkastus objektus po žeme. Palyginti su wavelet transformacijos algoritmu (5.1.3 poskyris), LOF algoritmas pasirodė geriau, kadangi šis gebėjo identifikuoti mažas anomalijas, kurių wavelet transformacijos algoritmas neaptiko.

5.2.4. Realus skenavimo duomenys iš realių skenavimų

Šiame poskyryje pateikiami rezultatai, gauti pritaikius vietinio nukrypimo faktoriaus algoritmą dviem skenavimo aikštelėms naudojant skirtingus kaimynų skaičius ($k = 15, k = 50, k = 100, k = 200$). Rezultatų vizualizacijos pateiktos 27 ir 28 paveiksluose.




27 pav. Vietinio nukrypimo faktoriaus algoritmo rezultatai pirmajai aikštelei, kai kaimynų skaičius yra: a) 15, b) 50, c) 100, d) 200.

Pirmajai aikštelei pritaikius LOF algoritmą su kaimynų skaičiumi $k = 15$ (27 paveikslo (a) dalis), stebimas didelis algoritmo pažymėtų anomalijų skaičius visoje skenavimo aikštelėje. Pažymėti taškai išsidėsto ne tik užkastų sprogmenų vietose, bet ir didelėje likusio matavimo zonos plote. Šiuo atveju algoritmas teisingai pažymėjo 3 iš 10 sprogmenų.

Iš 27 paveikslo (b) dalies, kai kaimynų skaičius yra $k = 50$, galima pastebėti algoritmo pažymėtų anomalijų koncentraciją ties užkastų sprogmenų lokacijomis. Kiti algoritmo pažymėti taškai daugiausia telkiasi skenuoto ploto kampe. Šis rezultatas yra geresnis nei su $k = 15$ kaimynų skaičiumi,

kurio atveju klaidingai pažymėtų anomalijų skaičius buvo didelis. Šiuo atveju algoritmas gebėjo teisingai atpažinti 4 iš 10 užkastų sprogmenų vietų.

Toliau didinant kaimynų skaičių iki $k = 100$ ir $k = 200$ (27 paveikslo (c) ir (d) dalys), algoritmo pažymėtų anomalijų koncentracija ties sprogmenų vietomis didėja. Tačiau gautas rezultatas išlieka analogiškas atvejui, kai kaimynų skaičius $k = 50$, kadangi algoritmas ir toliau identifikuoja 4 iš 10 sprogmenų vietų.



28 pav. Vietinio nukrypimo faktoriaus algoritmo rezultatai antrajai aikštelei, kai kaimynų skaičius yra: a) 15, b) 50, c) 100, d) 200.

LOF algoritmą pritaikius antrajai aikštelei su kaimynų skaičiumi $k = 15$ (28 pav. (a) dalis), pastebimas klaidingai pažymėtų anomalijų tolygus išsidėstymas visoje skenavimo zonoje. Nepaisant didelio klaidingai pažymėtų anomalijų tankio, algoritmui pavyko teisingai identifiikuoti vieną sprogmenų lokaciją.

27 paveikslo (b) dalyje, kai kaimynų skaičius yra $k = 50$. Lyginant su $k = 15$ atveju, stebimas algoritmo klaidingai pažymėtų anomalijų sumažėjimas, tačiau bendras rezultatas išlieka panašus. Esant šiam ($k = 50$) kaimynų skaičiui, algoritmas sugebėjo identifiikuoti vieną užkastą sprogmenų vietą. Taip pat pastebimas klaidingai pažymėtų anomalijų telkimas aplink tam tikras vietas visame skenavimo plote.

Kaimynų skaičių didinant iki $k = 100$ ir $k = 200$ (28 pav. (c) ir (d) dalys), algoritmo pažymėtų anomalijų koncentracija didėja tose pačiose vietose kaip ir esant $k = 50$. Šis rezultatas gali rodyti, jog šiose vietose po žeme gali būti kitų, su sprogmenimis nesusijusių feromagnetinių objektų. Vis dėlto, vertinant algoritmo aptiktų sprogmenų lokacijas, šie atvejai išlieka vienodi $k = 50$ atvejui, kadangi algoritmas ir toliau identifiukuoja tik 1 iš 11 užkastų sprogmenų vietų.


Lyginant abiejų teritorijų analizės rezultatus, gautus taikant vietinio nukrypimo faktoriaus algoritmą, galima teigti, jog šis metodas geba atpažinti magnetines anomalijas. Tačiau 5.1.4 poskyryje aprašyti rezultatai pasižymi didesniu aptikimo tikslumu, todėl galima daryti išvadą, jog wavelet transformacijos algoritmas yra efektyvesnis realių skenavimų atveju. Nepaisant to, LOF algoritmas gali būti naudojamas kaip pagalbinis įrankis sprogmenų paieškose. Šio algoritmo tikslumas pri-

klauso nuo pasirinkto kaimynų skaičiaus, todėl šio parametro pasirinkimas yra esminis patikimam rezultatų gavimui.

5.3. Analitinio signalo amplitudės algoritmas

5.3.1. Sintetinis signalas

Analitinio signalo amplitudės algoritmą pritaikius sintetiniam signalui, buvo siekiama įvertinti, kaip skirtingų amplitudės slenksčių pasirinkimas lemia magnetinių anomalijų aptikimą. Šio algoritmo rezultatai pritaikyti sintetiniam signalui pavaizduoti 29 pav.



29 pav. Analitinio signalo amplitudės algoritmo rezultatai sintetiniam signalui, atitinkamai parinkus amplitudės slenksčius procentiliais: a) 96%, b) 97%, c) 98%, d) 99%.

Pritaikius AAS algoritmą sintetiniam signalui su pasirinktu 96% procentiliu (29 (a) pav.), gaunama, kad aptinkamas labai didelis skaičius anomalijų visame signale. Matoma, jog abi magnetinių anomalijų vietos yra pažymėtos, tačiau dėl itin didelio pažymėtų anomalijų triukšmo šios nebūtų pastebimos bendrame fone.

Amplitudės slenksčio procentilį padidinus iki 97% (29 (b) pav.), pastebimas klaidingų anomalijų skaičiaus sumažėjimas visoje srityje. Vis dėlto, gautas rezultatas išlieka ganėtinai panašus į anksčiau aprašytą atvejį, o pagrindinių magnetinių anomalijų lokalizacija dar nėra pakankamai aiški.

Amplitudės slenksčio procentilį parinkus kaip 98% (29 (c) pav.), klaidingai aptinkamų anomalijų kiekis radikaliai sumažėja, o pagrindinės magnetinių anomalijų vietos tampa aiškiau lokalizuotos.


Kai amplitudės slenksčio procentilis parenkamas kaip 99% (29 (d) pav.), klaidingai aptinkamos anomalijos yra visiškai pašalinamos. Išlieka tik stipriausios analitinio signalo amplitudės, kurios sutampa su pagrindinėmis sintetinėmis anomalijomis. Nors toks slenkstis padeda atrinkti tik stipriausias amplitudes, tačiau kitais atvejais, kai tiriamos silpnesnės magnetinės anomalijos, toks slenkstis gali lemti jų neaptikimą.

Taigi, sintetiniam signalui pritaikius AAS metodą su skirtingais amplitudžių slenksčių procentiliais, gaunama, jog didėjant procentiliui mažėja klaidingų anomalijų skaičius, o pagrindinės magnetinės anomalijos tampa aiškiau išskiriamos.

Palyginus trijų algoritmų rezultatus, aprašytus 5.1.1 ir 5.2.1 poskyriuose, galima daryti išvadą, jog wavelet transformacijos algoritmas ir analitinio signalo amplitudės algoritmas parodė geriausius rezultatus sintetiniam signalui, atpažindami abi magnetines anomalijas, tuo tarpu vietinio nukrypimo faktoriaus algoritmas gebėjo atpažinti tik vieną anomaliją.

5.3.2. Realaus skenavimo su MagNIMBUS magnetometru duomenys iš internetinio šaltinio

Analitinio signalo amplitudės algoritmą pritaikius MagNIMBUS magnetometro duomenims iš internetinio šaltinio, buvo vertinama, kaip skirtingi amplitudės slenksčiai lemia magnetinių anomalijų aptikimą realiuose skenavimuose. Šio tyrimo rezultatai pavaizduoti 30 paveiksle.



30 pav. Analitinio signalo amplitudės algoritmo rezultatai MagNIMBUS magnetometro duomenims, atitinkamai parinkus amplitudės slenksčius procentiliais: a) 80%, b) 85%, c) 90%, d) 95%.


Taikant AAS metodą realiems MagNIMBUS magnetometro duomenims iš internetinio šaltinio, kai amplitudės slenksčio procentilis parenkamas kaip 80% (30 (a) pav.), tuomet pastebimas didelis pažymėtų anomalijų triukšmas visoje skenavimo zonoje. Nors dalis aptiktų anomalijų sutampa su užkastų sprogmenų vietomis, tačiau iš didelio pažymėtų anomalijų triukšmo šios nėra aiškiai lokalizuotos. Vadinas, toks žemas slenkstis lemia per didelį algoritmo jautrumą ir nėra tinkamas sprogmenų ieškojimui.

Didinant amplitudės slenksčio procentilį (30 (b), (c), (d) pav.), pastebimas klaidingai pažymėtų anomalijų mažėjimas. Kai amplitudės slenksčio procentilis parenkamas kaip 95%, matoma, jog algoritmo aptiktos anomalijos telkiasi aplink užkastų objektų sritis, o klaidingai pažymėtų anomalijų skaičius lieka minimalus.

Palyginus trijų algoritmų rezultatus, pateiktus 5.1.2 ir 5.2.2 poskyriuose, galima daryti išvadą, jog visi algoritmai tinka realių skenavimų su MagNIMBUS magnetometru analizei, kadangi kiekvienas iš jų identifikavo visas tris magnetines anomalijas.

5.3.3. Realaus skenavimo su DRONEmag GSMP-35U magnetometru duomenys iš internetinio šaltinio

DRONEmag GSMP-35U magnetometro duomenims iš internetinio šaltinio pritaikius AAS algoritmą, siekta įvertinti magnetinių anomalijų aptikimo priklausomybę nuo skirtingų amplitudės procentilinių slenksčių. Šios analizės rezultatai pateikti 31 paveiksle.



31 pav. Analitinio signalo amplitudės algoritmo rezultatai DRONEmag GSMP-35U magnetometro duomenims, atitinkamai parinkus amplitudės slenksčius procentiliais: a) 80%, b) 85%, c) 90%, d) 95%.

Pritaikius analitinio signalo amplitudės algoritmą su 80% procentiliniu slenksčiu (30 pav. (a) dalis), stebimas didelis algoritmo pažymėtų anomalijų skaičius visoje skenavimo zonoje, išsidėstęs dvejomis juostomis. Nors su šiuo slenksčiu algoritmas pažymėjo sprogmenis, tačiau dėl didelio klaidingų žymų skaičiaus nėra įmanoma gerai lokalizuoti sprogmenų vietų. Todėl 80% procentilinis slenkstis yra per žemas patikimai užkastų sprogmenų lokalizacijai.

Padidinus procentilinį slenkstį iki 85% (30 pav. (b) dalis), stebimas klaidingai pažymėtų anomalijų sumažėjimas. Vis dėlto, nepaisant sumažėjusio klaidingų žymų kiekio, sprogmenų lokacijų atpažinimas vis dar išlieka sudėtingas.


30 pav. (c) dalyje pavaizduoti rezultatai, gauti taikant 90% procentilinį slenkstį. Iš rezultatų galima pastebėti, kad esant šiai slenkstinei ribai sprogmenų lokacijos tampa aiškesnės, o klaidingai pažymėtų anomalijų triukšmas sumažėja. Tačiau matoma, jog šiuo atveju pažymėtos tik dvi sprogmenų vietos iš trijų. Taip pat vis dar liko pavienių žymų per visą skenavimo plotą.

Taikant 95% procentilinį slenkstį (30 pav. (d) dalis), rezultatai rodo, kad klaidingai pažymėtų anomalijų praktiškai nebelieka. Nepaisant to, toks slenkstinės ribos pasirinkimas lemia, jog algoritmas aptinka tik vieną sprogmenų lokaciją, todėl šis slenkstis yra per aukštas patikimai užkastų sprogmenų lokalizacijai.

Palyginus trijų algoritmų rezultatus, pateiktus 5.1.3 ir 5.2.3 poskyriuose, galima daryti prielaidą, jog realių skenavimų, atliktų naudojant DRONEmag GSMP-35U magnetometrą, atveju efektyviausias algoritmas yra vietinio nukrypimo faktoriaus algoritmas, identifikavęs visas tris magnetines anomalijas. Tuo tarpu wavelet transformacijos bei analitinio signalo amplitudės algoritmai sugebėjo aptikti dvi sprogmenų lokacijas iš trijų. Taip pat, palyginus šiuos rezultatus su 5.3.2 poskyryje pateiktais rezultatais, galima teigti, jog algoritmo aptikimo efektyvumui didelę įtaką turi magnetometras, su kuriuo buvo atliekami skenavimai. Šis aspektas taip pat aprašytas 5.1.3 poskyryje.

5.3.4. Realus skenavimo duomenys iš realių skenavimų

Šiame poskyryje pateikiami rezultatai, gauti pritaikius analitinio signalo amplitudės algoritmą dviem skenavimo aikštelėms, taikant skirtingus procentilinius slenksčius (90%, 95%, 98%, 99%). Šių eksperimentų rezultatų vizualizacijos pateiktos 32 ir 33 paveiksluose.




32 pav. Analitinio signalo amplitudės algoritmo rezultatai pirmajai skenavimo zonai, atitinkamai parinkus amplitudės slenksčius procentiliais: a) 90%, b) 95%, c) 98%, d) 99%.

Pirmajai skenavimo aikštei pritaikius AAS algoritmą su 90% procentiliniu slenksčiu (32 paveikslo (a) dalis), pastebimas didelis algoritmo pažymėtų anomalijų skaičius visoje skenavimo aikštelėje. Dalis užkastų sprogmenų lokacijų yra aiškiai išskiriamos, tačiau sprogmenų, esančių arti skenavimo zonos ribų, lokalizacija išlieka sudėtinga dėl didelio klaidingai pažymėtų anomalijų triukšmo. Esant šiam slenksčiui, algoritmas identifikuoja 4 sprogmenų lokacijas iš 10.

32 paveikslo (b) dalyje pateikti rezultatai, gauti taikant 95% procentilinį slenkstį. Matomas algoritmo klaidingai pažymėtų anomalijų koncentracijos sumažėjimas ties zonos ribomis, todėl sprogmenų lokacijos tampa dar aiškesnės nei ankstesniu atveju. Tačiau sprogmenų, esančių arti zonos ribų, lokalizacija išlieka sudėtinga dėl vis dar didelio klaidingų anomalijų skaičiaus. Nepaisant to, šis rezultatas yra geresnis nei taikant 90% slenkstį, kadangi šiuo atveju galima aiškiai identifikuoti 6 iš 10 sprogmenų lokacijų.

Didžiausias algoritmo efektyvumas pasiektas pritaikius 98% procentilinį slenkstį (32 paveikslo (c) dalis). Esant šiai slenkstinei ribai, visos algoritmo identifikuotos sprogmenų lokacijos yra aiškiai išskiriamos. Nors, kaip ir ankstesniu atveju taikant 95% slenkstį, algoritmas identifikavo 6 sprogmenų vietas iš 10, tačiau šiuo atveju šios lokacijos yra vizualiai ryškesnės ir lengviau atpažįstamos. Kaip ir ankstesniuose rezultatuose, klaidingai pažymėtos anomalijos koncentruojasi matavimo zonos ribų srityse.

Padidinus procentilinį slenkstį iki 99% (32 paveikslo (d) dalis), pastebima, jog šiuo atveju algoritmas identifikuoja 5 iš 10 sprogmenų. Tai rodo, kad esant tokiai ribai, dalis sprogmenų nebėra aptinkama, todėl tokia slenkstinė riba jau yra per didelė patikimai sprogmenų lokalizacijai.



33 pav. Analitinio signalo amplitudės algoritmo rezultatai antrajai skenavimo zonai, atitinkamai parinkus amplitudės slenksčius procentiliais: a) 90%, b) 95%, c) 98%, d) 99%.

Analitinio signalo amplitudės algoritmą pritaikius antrajai skenavimo aikštei su 90% procentiniu slenksčiu (33 pav. (a) dalis), pastebimas klaidingai pažymėtų anomalijų tolygus išsidėstymas visoje skenavimo zonoje. Dėl didelio klaidingai pažymėtų anomalijų kiekio sprogmenų identifikavimas šiuo atveju nėra patikimas.

Procentilinį slenkstį padidinus iki 95% (33 paveikslo (b) dalis), stebimas klaidingai pažymėtų anomalijų sumažėjimas. Tačiau, kaip ir ankstesniu atveju, sprogmenų identifikavimas nėra patikimas dėl vis dar ganėtinai didelio klaidingų žymų skaičiaus.

Kaip ir ankstesnėje matavimo zonoje, geriausias rezultatas gautas taikant 98% (33 pav. (c) dalis) procentilinį slenkstį. Su šia slenkstine riba užkastų sprogmenų lokacijos tampa aiškiau išskiriamos, o klaidingų anomalijų triukšmas reikšmingai sumažėja. Šiuo atveju algoritmas sėkmingai aptiko 9 iš 11 sprogmenų lokacijų. Vis dėlto pavienės klaidingos anomalijos vis dar išlieka, kas apsunkina tikslią vizualinę sprogmenų lokalizaciją.

Taikant 99% procentilinį slenkstį (33 paveikslas (d) dalis), gauti rezultatai rodo, kad ši slenkstinė riba yra per didelė patikimam sprogmenų aptikimui. Lyginant su atveju, kai taikytas 98% procentinis slenkstis, dalis anksčiau identifikuotų sprogmenų nebėra aptinkami. Šiuo atveju algoritmas identifikavo 5 sprogmenų lokacijas iš 11.

Lyginant abiejų teritorijų analizės rezultatus, gautus taikant analitinio signalo amplitudės algoritmą, galima daryti išvadą, jog šis metodas sugeba atpažinti magnetines anomalijas geru tikslumu. Taigi, šis algoritmas gali būti taikomas kaip pagalbinis įrankis sprogmenų paieškos uždaviniuose. Vis dėlto algoritmo aptikimo tikslumas priklauso nuo pasirinkto slenksčio, todėl šio parametro pasirinkimas yra esminis patikimam rezultatų interpretavimui.

Palyginus analitinio signalo amplitudės algoritmo rezultatus su wavelet transformacijos (5.1.4 poskyris) ir vietinio nukrypimo faktoriaus (5.2.4 poskyris) algoritmų rezultatais, galima daryti išvadą, jog analitinio signalo amplitudės algoritmas yra tinkamiausias realių tyrimų atveju. Wavelet transformacijos algoritmas identifikavo 11 iš 21 sprogmenų lokacijų, o LOF algoritmas sėkmingai aptiko 5 iš 21 sprogmenų. Tuo tarpu AAS algoritmas pasižymėjo didžiausiu efektyvumu abiejose nagrinėtose teritorijose, aptikęs 15 iš 21 sprogmenų lokacijų.

Išvados ir rekomendacijos

1. Wavelet transformacijos algoritmas ir analitinio signalo amplitudės algoritmas parodė geriausius rezultatus sintetinio signalo atveju, atpažindami abi magnetines anomalijas, tuo tarpu vietinio nukrypimo faktoriaus algoritmas sugebėjo atpažinti tik vieną anomaliją.
2. MagNIMBUS magnetometro duomenims iš internetinio šaltinio visi nagrinėti algoritmai identifikavo visas magnetines anomalijas.
3. DRONEmag GSMP-35U magnetometro duomenų iš internetinio šaltinio atveju efektyviausias pasirodė vietinio nukrypimo faktoriaus algoritmas, identifikavęs visas tris magnetines anomalijas. Tuo tarpu wavelet transformacijos bei analitinio signalo amplitudės algoritmai sugebėjo aptikti dvi iš trijų sprogmenų lokacijų.
4. Algoritmo aptikimo efektyvumui įtakos turi magnetometras, su kuriuo buvo atliekami matavimai, tai nustatyta analizuojant MagNIMBUS ir DRONEmag GSMP-35U duomenis.
5. Realų tyrimų Lietuvoje atveju analitinio signalo amplitudės algoritmas pasirodė efektyviausias, aptikdamas 15 iš 21 sprogmenų lokacijų. Wavelet transformacijos algoritmas identifikavo 11 iš 21 sprogmenų lokacijų, LOF algoritmas sėkmingai aptiko 5 iš 21 sprogmenų.
6. Visi tirti algoritmai realių skenavimų Lietuvoje metu neidentifikavo visų sprogmenų lokacijų, todėl šie algoritmai turėtų būti naudojami kaip pagalbinės priemonės sprogmenų ieškojime.

Rekomendacijos:

- Išbandyti wavelet transformacijos algoritmą su įvairiomis slenkstinėmis vertėmis, siekiant pagerinti anomalijų identifikavimą.
- Vietinio nukrypimo faktoriaus algoritmas yra jautrus parametrai k (kaimynų skaičiui). Taigi, prieš taikant šį algoritmą, būtina atlikti išankstinę analizę optimalių parametrų paieškai.
- Prieš taikant analitinio signalo amplitudės algoritmą patikrinti šį su įvairiomis slenkstinėmis vertėmis, kadangi tai gali pagerinti anomalijų identifikavimą.

Ateities tyrimų planas

- Apmokyti mašininio mokymosi modelį sprogmenų tipo klasifikavimui iš magnetometro duomenų, siekiant atskirti skirtingus sprogmenis, nepradėjus kasimo darbų.
- Apmokyti konvoliucinį neuroninį tinklą, jog šis gebėtų atpažinti sprogmenis iš duomenų vizualizacijų.
- Integruoti papildomus duomenis, tokius kaip georadaro duomenys, siekiant pasiekti didesnę tikslumą aptinkant sprogmenis.

Literatūros šaltiniai

- [1] Filippo Accomando and Giovanni Florio. Drone-borne magnetic gradiometry in archaeological applications. *Sensors*, 24(13), 2024.
- [2] Elijah Achuoth Deng, Kennedy O. Doro, and Carl-Georg Bank. Suitability of magnetometry to detect clandestine buried firearms from a controlled field site and numerical modeling. *Forensic Science International*, 314:110396, 2020.
- [3] Daniel Barrish and Jan van Vuuren. Enhancement of the local outlier factor algorithm for anomaly detection in time series. In Hossein Moosaei, Ilias Kotsireas, and Panos M. Pardalos, editors, *Dynamics of Information Systems*, pages 171–188, Cham, 2025. Springer Nature Switzerland.
- [4] T. A. Bowen, E. Zhivun, A. Wickenbrock, V. Dumont, S. D. Bale, C. Pankow, G. Dobler, J. S. Wurtele, and D. Budker. A network of magnetometers for multi-scale urban science and informatics. *Geoscientific Instrumentation, Methods and Data Systems*, 8(1):129–138, 2019.
- [5] Marcio Maciel Cavalcanti, Marcelo Peres Rocha, Marcelo Lawrence Bassay Blum, and Welitom Rodrigues Borges. The forensic geophysical controlled research site of the university of brasilia, brazil: Results from methods gpr and electrical resistivity tomography. *Forensic Science International*, 293:101.e1–101.e21, 2018.
- [6] Jullian Dominic Ducut, Melchizedek Alipio, Phoebe Joanne Go, Ronnie Concepcion II, Ryan Rhay Vicerra, Argel Bandala, and Elmer Dadios. A review of electrical resistivity tomography applications in underground imaging and object detection. *Displays*, 73:102208, 2022.
- [7] SPH Engineering. Geohammer data processing software. https://shop.sphengineering.com/products/geohammer-free?srltid=AfmBOopazZpk7yu6fMLiTv3jKXU34_04IDeeblwl6BvroelL2UBw9Q5nF, 2025. Version 2.0.7.
- [8] Sara Yehia Abdel Fatah, Fatma Taher, Mohamed Khaled Gad Attya, Karim Ahmed Hosni, Moath Alathbah, Thamer Alghamdi, Mohamed Fathy Abo Sree, and M. Abdel-Aleim M. Advancements in underground object detection: Exploring emerging techniques and technologies. In *2024 International Telecommunications Conference (ITC-Egypt)*, pages 852–857, 2024.
- [9] Songtong Han, Xiaoli Rong, Leixiang Bian, Mingyou Zhong, and Lining Zhang. The application of magnetometers and electromagnetic induction sensors in uxo detection. *E3S Web of Conferences*, 131:01045, 01 2019.
- [10] Charles R. Harris, K. Jarrod Millman, Stéfan J. van der Walt, Ralf Gommers, Pauli Virtanen, David Cournapeau, Eric Wieser, Julian Taylor, Sebastian Berg, Nathaniel J. Smith, Robert Kern, Matti Picus, Stephan Hoyer, Marten H. van Kerkwijk, Matthew Brett, Allan Haldane, Jaime Fernández del Río, Mark Wiebe, Pearu Peterson, Pierre Gérard-Marchant, Kevin Sheppard, Tyler Reddy, Warren Weckesser, Hameer Abbasi, Christoph Gohlke, and Travis E. Oliphant. Array programming with NumPy. *Nature*, 585(7825):357–362, September 2020.
- [11] Pek Chun Hoe, Ronald Francis, Akhmal Sofia Asykin, Mohd Al-Amin Bin Abdullah, and Muhammad Anwar Bin Ahmad. Enhancing the teaching and learning process of faraday’s

and lenz's laws in electromagnetic induction using em-kit. *International Journal of Business Studies and Education*, 2(1), 2024.

- [12] J. D. Hunter. Matplotlib: A 2d graphics environment. *Computing in Science & Engineering*, 9(3):90–95, 2007.
- [13] Sergejs Kucenko and Matīss Brants. Uav-based magnetometer comparison: Uxo test. <https://www.sphengineering.com/news/uav-based-magnetometer-comparison-uxo-test>, February 2024. Accessed: 2025-05-19.
- [14] Gregory R. Lee, Ralf Gommers, Filip Wasilewski, Kai Wohlfahrt, and Aaron O’Leary. Pywavelets: A python package for wavelet analysis. *Journal of Open Source Software*, 4(36):1237, 2019.
- [15] Yuri Álvarez López, María García-Fernández, Guillermo Álvarez Narciani, and Fernando Las-Heras Andrés. Unmanned aerial vehicle-based ground-penetrating radar systems: A review. *IEEE Geoscience and Remote Sensing Magazine*, 10(2):66–86, 2022.
- [16] Wes McKinney et al. Data structures for statistical computing in python. In *Proceedings of the 9th Python in Science Conference*, volume 445, pages 51–56. Austin, TX, 2010.
- [17] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.
- [18] Y. H. Pei, H. G. Yeo, X. Y. Kang, S. L. Pua, and John Tan. Magnetic gradiometer on an auv for buried object detection. In *OCEANS 2010 MTS/IEEE SEATTLE*, pages 1–8, 2010.
- [19] A. Perrone, V. Lapenna, and S. Piscitelli. Electrical resistivity tomography technique for landslide investigation: A review. *Earth-Science Reviews*, 135:65–82, 2014.
- [20] Mark D. Prouty and Mikhail Tchernychev. Real-time threat detection using magnetometer arrays. In Edward M. Carapezza, editor, *Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security, Defense, and Law Enforcement Applications XV*, volume 9825, page 98250A. International Society for Optics and Photonics, SPIE, 2016.
- [21] Vijaya Kumar Reddy, Kiran Kumar Siramoju, and Pradip Sircar. Object detection by 2-d continuous wavelet transform. In *2014 International Conference on Computational Science and Computational Intelligence*, volume 1, pages 162–167, 2014.
- [22] Ahmed Salem, Dhananjay Ravat, T.Jeffrey Gamey, and Keisuke Ushijima. Analytic signal approach and its applicability in environmental magnetic investigations. *Journal of Applied Geophysics*, 49(4):231–244, 2002.
- [23] Stéfan van der Walt, Johannes L. Schönberger, Juan Nunez-Iglesias, François Boulogne, Joshua D. Warner, Neil Yager, Emmanuelle Gouillart, Tony Yu, and the scikit-image contributors. scikit-image: image processing in Python. *PeerJ*, 2:e453, 6 2014.

- [24] Guido Van Rossum and Fred L Drake Jr. *Python reference manual*. Centrum voor Wiskunde en Informatica Amsterdam, 1995.
- [25] Pauli Virtanen, Ralf Gommers, Travis E. Oliphant, Matt Haberland, Tyler Reddy, David Cournapeau, Evgeni Burovski, Pearu Peterson, Warren Weckesser, Jonathan Bright, Stéfan J. van der Walt, Matthew Brett, Joshua Wilson, K. Jarrod Millman, Nikolay Mayorov, Andrew R. J. Nelson, Eric Jones, Robert Kern, Eric Larson, C J Carey, İlhan Polat, Yu Feng, Eric W. Moore, Jake VanderPlas, Denis Laxalde, Josef Perktold, Robert Cimrman, Ian Henriksen, E. A. Quintero, Charles R. Harris, Anne M. Archibald, Antônio H. Ribeiro, Fabian Pedregosa, Paul van Mulbregt, and SciPy 1.0 Contributors. SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. *Nature Methods*, 17:261–272, 2020.
- [26] Xiaofen Wang, Peng Wang, Xiaotong Zhang, Yadong Wan, Haodong Shi, and Wen Liu. Target electromagnetic detection method in underground environment: A review. *IEEE Sensors Journal*, 22(14):13835–13852, 2022.
- [27] Zeev Zalevsky, Yuri Bregman, Nizan Salomonski, and Hovav Zafrir. Resolution enhanced magnetic sensing system for wide coverage real time uxo detection. *Journal of Applied Geophysics*, 84:70–76, 2012.